PATENT ABSTRACTS OF JAPAN

(11)Publication number:

09-265435

(43)Date of publication of application: 07.10.1997

(51)Int.CI.

GOSF 12/16 G06F 12/16 3/06 G06F G06F 3/06 G06F 3/06 G06F 12/08 G06F 12/08

(21)Application number: 08-072934

(71)Applicant : HITACHI LTD

(22)Date of filing:

27.03.1996

(72)Inventor: YAMAMOTO AKIRA

MORISHITA NOBORU

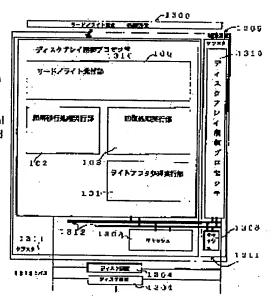
INOUE YASUO AZUMI YOSHIHIRO

(54) STORAGE DEVICE SYSTEM

(57)Abstract:

PROBLEM TO BE SOLVED: To improve storage efficiency without impairing reliability and to improve the relaibility of maintenance processing.

SOLUTION: Write data are stored by the format of a RAID (arrangement method for dividing records and storing the divided records in plural disk devices) 3 and cache management information is stored by the format of a RAID (arrangement method (double writing) for storing data having quite the same contents in two disk devices) 1. In the case of a disk controller 1305 constituted of plural clusters 1311, the storage format of data in each cluster is provided with redundancy, and in the case of executing maintenance processing, the storage of new data in a cache memory 1308 for executing maintenance is inhibited and data stored in the cache memory 1308 for executing maintenance are written in a cache memory 1308 in the other cluster 1311 or written in a disk device 1304.



LEGAL STATUS

[Date of request for examination]

09.03.2000

[Date of sending the examiner's decision of rejection]

21.05.2002

[Kind of final disposal of application other than the examiner's decision of rejection or application converted

registration]

[Date of final disposal for application]

[Patent number]

[Date of r gistration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

Copyright (C); 1998,2003 Japan Patent Office

(19)日本国特許庁 (JP)

(12) 公開特許公報(A)

(11)特許出願公開番号

特開平9-265435

(43)公開日 平成9年(1997)10月7日

(51) Int.Cl. ⁶	識別記号	庁内整理番号	ΡI				技術表示箇所
G06F 12/16	310	7623-5B	G06F	12/16		310Q	
	320	3 2 0 7623-5B				320L	
3/06	302			3/06		302A	
	306					306B	
	540					540	
		審査請求	未請求 請求	項の数16	OL	(全 25 頁)	最終頁に続く
(21)出願番号	特願平8-72934		(71)出願ノ	0000051	108		
				株式会	社日立	製作所	
(22)出願日	平成8年(1996)3		東京都	千代田	区神田駿河台	四丁目6番地	
			(72)発明者				
1 Share				神奈川」	県川崎	市麻生区王禅	寺1099番地 株
						作所システム	
			(72)発明者				
				神奈川」	具川崎	市麻生区王禅	寺1099番地 株
						作所システム	
			(72)発明者				
				神奈川」	具小田	原市国府津288	30番地 株式会
	•	•					ステム事業部内
	· · · · · ·		(74)代理人				
	•						最終頁に続く

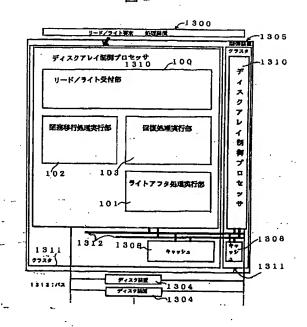
(54)【発明の名称】 記憶装置システム

(57)【要約】

【課題】 信頼性を損なうことなく記憶効率を従来に比べて向上させること、保守処理中の信頼性を向上させること。

【解決手段】 ライトデータをRAID3の形式で格納し、キャッシュの管理情報をRAID1の形式で格納する。また、複数クラスタで構成されるディスク制御装置の場合、それぞれのクラスタ内のデータの格納形式に冗長性を持たせ、保守処理を行なう際には、保守を行うキャッシュメモリには、新たにデータの格納を行なわないようにし、保守を行うキャッシュメモリにそれまで格納していたデータをもう一方のクラスタのキャッシュメモリに書き込むか、ディスク装置に書き込むようにする。

図 1



【特許請求の範囲】

【請求項1】 1つ以上の記憶装置と複数のクラスタを 有する制御装置から構成される記憶装置システムであっ て、

それぞれのクラスタが冗長性を備えたキャッシュメモリ と、

前記制御装置が、

各クラスタの前記キャッシュメモリが正常状態の時、前 記記憶装置のデータを各クラスタの前記キャッシュメモ リに格納する手段と、

処理装置からライト要求を受付け、該ライト要求に付随 して前記処理装置から受け付けたライトデータを前記キャッシュメモリに格納し、前記ライト要求を完了させる 手段とを有することを特徴とする記憶装置システム。

【請求項2】 前記クラスタの保守を行なう際の前処理として、保守対象のクラスタ内のキャッシュメモリ中の前記記憶装置にまだ書き込まれていないライトデータを、保守を行なわないクラスタのキャッシュメモリあるいは前記記憶装置に書き込む手段を有することを特徴とする請求項1記載の記憶装置システム。

【請求項3】 保守対象のクラスタ内のキャッシュメモリ中の前記記憶装置にまだ書き込まれていないライトデータを、保守を行なわないクラスタのキャッシュメモリあるいは前記記憶装置に書き込む手段と、

前記処理装置からリード/ライト要求を受付け、前記書 き込む手段の書き込み処理と並行してリード/ライト処理を実行する手段とを有することを特徴とする請求項2 記載の記憶装置システム。

【請求項4】 保守対象のクラスタの保守が完了した 後、保守が完了したクラスタ以外のキャッシュメモリ中 で、前記記憶装置にまだ書き込まれていないライトデー タを、保守が完了したクラスタ内のキャッシュメモリあ るいは前記記憶装置に書き込む手段を有することを特徴 とする請求項2記載の記憶装置システム。

【請求項5】 保守が完了したクラスタ以外のキャッシュメモリ中で、前記記憶装置にまだ書き込まれていないライトデータを、保守が完了した前記クラスタのキャッシュメモリあるいは前記記憶装置に書き込む手段を有する手段と、

前記処理装置からリード/ライト要求を受付け、前記書 き込む手段の書き込み処理と並行してリード/ライト処 理を実行する手段とを有することを特徴とする請求項4 記載の記憶装置システム。

【請求項6】 前記クラスタ内のキャッシュメモリが障害のために冗長性が失われたとき、障害を起こしたキャッシュメモリ中の前記記憶装置にまだ書き込まれていないライトデータを、障害を起こしたキャッシュメモリ以外のキャッシュメモリあるいは前記記憶装置に書き込む手段を有することを特徴とする請求項1記載の記憶装置システム。

【請求項7】 障害を起こしたキャッシュメモリ中の前記記憶装置にまだ書き込まれていないライトデータを、 障害を起こしたキャッシュメモリ以外のキャッシュメモリあるいは前記記憶装置に書き込む手段と

前記処理装置からリード/ライト要求を受付け、前記書 き込む手段の書き込み処理と並行してリード/ライト処理を実行する手段とを有することを特徴とする請求項6 記載の記憶装置システム。

【請求項8】 前記キャッシュメモリの冗長性が回復した後、冗長性が回復したキャッシュメモリ以外のキャッシュメモリ中で前記記憶装置にまだ書き込まれていないライトデータを、冗長性を回復したキャッシュメモリあるいは前記記憶装置に書き込む手段を有することを特徴とする請求項6記載の記憶装置システム。

【請求項9】 冗長性が回復したキャッシュメモリ以外のキャッシュメモリ中で、前記記憶装置にまだ書き込まれていないライトデータを、冗長性を回復したキャッシュメモリあるいは前記記憶装置に書き込む手段を有する手段と、

前記処理装置からリード/ライト要求を受付け、前記書 き込む手段の書き込み処理と並行してリード/ライト処理を実行する手段とを有することを特徴とする請求項4 記載の記憶装置システム。

【請求項10】 1つ以上の記憶装置と制御装置から構成される記憶装置システムであって、

複数のボードから構成され、前記記憶装置の一部のデータを格納するキャッシュメモリと、

複数のボードから構成され、前記キャッシュメモリに格 納されたデータの管理情報を格納する管理情報格納メモ リと、

前記キャッシュメモリ内のm (≥2) 枚のボードに前記記憶装置の内容の一部のデータを分割して格納し、前記データの内容を回復するための冗長データを前記キャッシュメモリ内のn (≥1) 枚のボードに格納する手段と、

前記管理情報を、前記管理情報メモリ内の2つ以上のボードに重複して格納する手段を有することを特徴とする記憶装置システム。

【請求項11】 前記キャッシュメモリおよび前記管理情報格納メモリのいずれも冗長性をもっている時、処理装置からライト要求を受付け、当該ライト要求に付随して前記処理装置から受け付けたライトデータを前記キャッシュメモリに格納し、前記ライト要求を完了させる手段を有することを特徴とする請求項10記載の記憶装置システム。

【請求項12】 前記キャッシュメモリおよび前記管理 情報格納メモリのいずれかが障害のため冗長性がなくなった時、処理装置からライト要求を受付け、そのライト 要求に付随して前記処理装置から受け付けたライトデー 夕を前記記憶装置に書き込んだ後、前記ライト要求を完 了させる手段を有することを特徴とする請求項10記載 の記憶装置システム。

【請求項13】 前記キャッシュメモリおよび前記管理情報格納メモリのいずれかが障害のため冗長性がなくなった時、キャッシュメモリ中で前記記憶装置にまだ書き込まれていないライトデータを、前記記憶装置に書き込む手段を有することを特徴とする請求項12記載の記憶装置システム。

【請求項14】 前記キャッシュメモリあるいは前記管理情報格納メモリのボードの保守を行なう際の前処理として、前記キャッシュメモリ中の前記記憶装置にまだ書き込まれていないライトデータを前記記憶装置に書き込む手段を有することを特徴とする請求項10記載の記憶装置システム

【請求項15】 前記キャッシュメモリあるいは前記管理情報格納メモリのボードの保守を行っている時、処理装置からライト要求を受付け、そのライト要求に付随して前記処理装置から受け付けたライトデータを前記記憶装置に書き込んだ後、前記ライト要求を完了させる手段を有することを特徴とする請求項14記載の記憶装置システム。

【請求項16】 前記キャッシュメモリ中の前記記憶装置にまだ書き込まれていないライトデータを前記記憶装置に書き込む手段を有する手段と、

処理装置からライト要求を受付け、そのライト要求に付随して前記処理装置から受け付けたライトデータを前記記憶装置に書き込んだ後、前記ライト要求を完了させる処理を前記書き込む手段の書き込み処理と並行に実行する手段とを有することを特徴とする請求項15記載の記憶装置システム。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、キャッシュメモリを有する記憶システムに係り、特にその高性能化、高信頼化に関するものである。

[0002]

【従来の技術】記憶システムの公知例として、以下に示すPattersonの論文が知られている。

【0003】エー、シー、エム、シグモッド コンファレンス プロシーディング、1988年、6月、ページ109-116 (D.Patterson, et al: A Case for Redundant A rraysof Inexpensive Disks(RAID)、ACM SIGMOD conference proceeding、Chicago、IL、June1-3、1988、pp. 109-116)

Pattersonの論文は、ディスクアレイ上のデータ配置に関する技術を開示したものである。

【0004】ディスクアレイは、ディスクシステムの高性能化、高信頼化を実現するための機構である。ディスクアレイでは、高性能化のために、物理的には複数のディスク装置を、処理装置に対しては1台の論理的なディ

スク装置に見せかける。一方、高信頼化のためには、データを格納したディスク装置に障害が発生した場合、データの回復を行うための冗長データを別のディスク装置 に格納しておく。

【0005】Pattersonの論文では、ディスクアレイ上の冗長データの配置方法についていくつかの技術が開示されている。以下、本発明に関係する冗長データの配置方法について説明する。

【0006】まったく同じ内容のデータを2つのディスク装置に格納する配置方法を、RAID1、あるいは、2重書きと呼んでいる。

【0007】処理装置が、論理的なディスク装置との間で、リード/ライト処理を行なう際の、リード/ライト単位となるデータの集合をレコードと呼ぶ。Pattersonの論文では、このレコードを分割して、複数のディスク装置に格納するデータ配置方法をRAID3と呼ばれる。RAID3では、n個の分割単位に対して1個の冗長データが作成される。

【0008】一方、レコードは分割せずに、1つのディスク装置に格納するデータ配置方法をRAID4、RAID5と呼んでいる。RAID4、RAID5では、複数のレコードから冗長データが作成される。

【0009】RAID1では、同じデータを2重に格納するため、ディスク装置の記憶容量が2倍必要となる。 したがって、信頼性は向上するが、価格は高くなる。

【0010】一方、RAID3、RAID4、RAID 5は、複数のデータに対し、1つの冗長データを作成すればよいため、記憶容量はそれ程増大しない。

【0011】RAID3では、レコードを複数のディス ク装置に分割して記録するため、処理装置から要求され るリード/ライト処理を実行する際、複数のディスク装 置を占有することになる。ディスク装置からデータをリ ード/ライトする場合、これに先立ち、シーク/サーチ 処理を実行する必要がある。データのリード/ライト時 間は、レコードを分割した数に比例して短くなるが、シ ーク/サーチ時間は、短くならない。このため、RAI D3では、レコードを1つ読み書きするような場合、R AID3を構成する1つ1つのディスク装置を独立に動 作させた場合に比較すると、性能劣化が激しい。ただ し、RAID3の場合、1回のリード/ライトデータ量 が、シーク/サーチ時間を無視できるだけの量となれ ば、充分な性能を得ることができる。さらに、専用のハ ードウェアを設ければ、ディスクアレイの制御プログラ ムからは、RAID3を1つのディスク装置として制御 できるため、ディスクアレイの制御プログラムを大幅に 簡略して作成できる。

【0012】RAID5の場合、レコードは1つのディスク装置に格納されるため、ディスク装置からレコードを1つリードする場合、1台のディスク装置しか占有しない。ただし、書き変えられた内容と、そのレコードの

更新前の値、冗長データの以前の値とから、新しい冗長データの値を作成する。このため、レコードの更新前の値と冗長データの以前の値の読み出し、レコードと新しい冗長データの書き込み、と計4回のディスク装置へのリード/ライト処理の実行が必要となる。また、RAID4や、RAID5では、ディスクアレイの制御ソフトウェアは、個々のディスク装置を意識し、かつ、処理装置には、ディスクアレイを1つの論理的なデイスク装置に見せる必要があるため、複雑になる。

【0013】一方、特開平7-230362号は、複数のディスク装置を1つのボード上に搭載させるボードディスクに関する技術が開示されている。通常、保守処理は、ボード単位に実行される。この保守処理中にも、処理装置からのリード/ライト要求を受け付けられるように、複数のボード間で、ディスクアレイを構成するようにしている。

【0014】また、近年のディスクシステムにおいては、特開平5-189314号に見られるように、複数のディスク装置を制御する制御装置にキャッシュメモリを装備している。さらに、処理装置からライト要求を受け付けた場合、制御装置は、ライトデータをキャッシュメモリに書き込んだだけで、ライト要求を完了させる。キャッシュ内のライトデータは、制御装置が後からディスク装置に書き込むが、その前にキャッシュメモリに障すが発生すると、処理装置から見ると、ディスク装置に書き込んだデータが失われてしまったことになるため、重大な事態になる。このため、キャッシュメモリを不揮発化したり、2重化してライトデータを2重に格納するような技術が開示されている。また、このような時、キャッシュメモリの管理情報も不揮発化あるいは2重化する。

【0015】さらに、近年のディスクシステムに対しては、無停止化の要求が強い。特に、保守処理を行なう際、処理装置からのリード/ライト要求を受付ながら、保守処理を実行可能にする必要となる。このような要求に対応して、特開平7-306844号に見られるように、ディスクシステムを2つのクラスタから構成し、一方のクラスタを閉塞して保守処理を実行して、もう一方のクラスタで処理装置からのリード/ライト要求を受付けるように構成したものがある。

【0016】その他、ディスクシステムの高性能化方式 として、ライトアフタ制御を行うディスクキャッシュを 利用した技術が、以下の通り開示されている。

【0017】特開昭55-157053号では、ディスクキャッシュを有する制御装置において、ライトアフタ処理を利用してライト要求を高速化に関する技術が開示されている。具体的には、制御装置は、処理装置から受け付けたライトデータをキャッシュ内に書き込んだ段階で、ライト処理を完了させる。処理装置から受け付け、キャッシュ内に格納したデータのディスク装置への書き

込みは、後から、制御装置のライトアフタ処理によって 実行される。

【0018】特開昭59-135563号では、高信頼性を保証しながらライト処理を高速化する制御装置に関する技術が開示されている。

【0019】特開昭59-135563号では、制御装置内にキャッシュメモリ以外に不揮発性メモリを有し、処理装置から受け取ったライトデータをキャッシュメモリと不揮発性メモリに格納する。ディスク装置へのライトデータの書き込みは、制御装置がライトアフタ処理によって実行する。これにより、ライトアフタ処理の高信頼化を図る。

【0020】一方、特開昭60-114947号では、 2重書きディスク装置を制御するディスクキャッシュを 有する制御装置に関する技術が開示されている。

【0021】特開昭60-114947号では、制御装置は、処理装置から受け取ったライト要求に対し、一方のディスク装置とキャッシュメモリに、処理装置から受け取ったライトデータを書き込む。もう一方のディスク装置には、制御装置が、処理装置からのリード/ライト要求とは非同期に、キャッシュメモリに格納したライトデータを後から書き込む。制御装置が、処理装置からのリード/ライト要求とは非同期に、キャッシュメモリに格納したライトデータをディスク装置に後から書き込む動作をライトアフタ処理と呼ぶ。

【0022】特開平2-37418号では、2重書きディスク装置をディスクキャッシュを利用した高性能化に関する技術が開示されている。

【0023】特開平3-37746号では、ディスクキャッシュを有し、ライトアフタ処理を実行する制御装置において、ライトアフタ処理を効率よく実行することを目的としたディスクキャッシュ内のライトアフタデータの管理データ構造についての技術が開示されている。

【0024】また、ディスクアレイに関しては次のような技術が開示されている。

【0025】特開平4-302020号では、可変長レコードの格納を許したディスク装置を用いたディスクアレイに関する技術が開示されている。

【0026】特開平5-46324号では、ディスクアレイを構成する個々のディスク装置にパリティレコードの更新値を作成する機能を分散する技術が開示されている。

【0027】特開平7-44326号では、ディスク装置に2つのアクチェエータ、あるいは、リード処理とライト処理を並列に実行できるヘッドを利用して、パリティレコードの更新値を効率良く作成する技術が公開されている。

[0028]

【発明が解決しようとする課題】特開平5-18931 4号では、ライトデータをキャッシュメモリに2重に格 納する。このため、キャッシュメモリの記憶容量が2倍 必要になる。同様に、キャッシュメモリの管理情報も2 重化しているため、必要な記憶容量が2倍になる。

【0029】すなわち、上記した従来の技術では、ライトデータやキャッシュの管理情報を単に2重化しているだけでであるため、記憶効率が悪いという問題がある。 【0030】さらに、特開平5-189314号および特開平7-306844号では、保守処理中においてライトデータを冗長化することについては配慮されておらず、保守処理中に障害が発生すると、ライトデータ等が消失する可能性がある。

【0031】本発明の第1の目的は、ライトデータやキャッシュの管理情報の信頼性を損なうことなく記憶効率を向上させることができる記憶システムを提供することにある。

【0032】第2の目的、保守処理中の信頼性についても向上させることができる記憶システムを提供することにある。

[0033]

【課題を解決するための手段】本発明においては、上記第1の目的を達成するために、ライトデータをRAID3の形式で格納し、キャッシュの管理情報をRAID1の形式で格納するようにしたことを特徴とする。

【0034】また、上記第2の目的を達成するためには、ディスク制御装置が複数のクラスタにより構成されることが前提となる。この場合、それぞれのクラスタ内のデータの格納形式に冗長性を持たせておき、クラスタ間ではキャッシュメモリに格納するデータを重複させないようにし、保守処理を行なう際には、保守を行うキャッシュメモリは新たにデータの格納を行なわないようにし、保守を行うキャッシュメモリにそれまで格納していたデータをもう一方のクラスタのキャッシュメモリに書き込むか、ディスク装置に書き込むようにしたことを特徴とする。

【0035】本発明においては、上記のように、ライトデータやキャッシュの管理情報の信頼性を損なうことなく記憶効率を向上させるために、ライトデータをRAID3の形式で格納する。この場合、キャッシュメモリは、通常、ボードが保守単位となるため、ボード間で、RAID3を構成する。ただし、これだけでは、キャッシュメモリのデータ格納形式に、RAID3を適用しただけである。また、ボード間で、RAID3を構成する技術も、特開平7-230362号で開示されているボードディスクの構成方法をキャッシュメモリに適用したにすぎない。

【0036】そこで、本発明では、ライトデータをRA ID3の形式で格納し、キャッシュの管理情報をRA ID1の形式で格納する。これは、キャッシュの管理情報は、更新の単位が小さいため、RAID3の形式で記録すると、冗長データを作成している1組の管理情報の集

合を部分的に更新することが多くなるため、管理情報の 更新に伴い、キャッシュメモリからの読み出しが発生 し、更新性能が低下するからである。RAID1の形式 で記録することにより、この性能劣化を防ぐことができ る。また、キャッシュメモリの管理情報は、キャッシュ メモリの大きさの比べて充分小さいため、この部分だけ RAID1の形式にしても記憶効率はそれ程悪くならない。

【0037】一方、ライトデータは処理装置がレコードという単位で更新するため、更新単位が大きく、ライトデータを複数のキャッシュメモリに分割して、冗長データを作成できる。しかも、キャッシュメモリの場合、ディスク装置のようにシークサーチ時間がないため、ライトデータを複数のキャッシュメモリに分割しても、性能的にも問題がない。以上により、ライトデータをRAID3の形式で格納し、キャッシュの管理情報をRAID1の形式で格納することにより、信頼性をそれほど損なうことなく、記憶効率を従来に比べて向上させることができる。

【0038】また、本発明では、上記のように、保守処理中の信頼性を向上させるために、それぞれのクラスタ内のデータの格納形式に冗長性を持たせ、クラスタ間で、キャッシュメモリに格納するデータを重複させないようにしておく。保守処理を行なう際には、保守を行うキャッシュメモリは、新たにデータの格納を行なわないようにし、保守を行うキャッシュメモリにそれまで格納していたデータを、もう一方のクラスタのキャッシュメモリに書き込むか、ディスク装置に書き込むようにする。保守を行なわないキャッシュメモリ上のデータも冗長性を持っている。これにより、保守処理中の信頼性を向上させることが可能になる。

[0039]

【発明の実施の形態】以下、本発明の実施の形態を図面を参照して説明する。

【0040】まず、第1の実施形態について説明する。

【0041】図1は、本発明を適用したディスクアレイ制御プロセッサの実施形態を示す構成図であり、図1のディスクアレイ制御プロセッサを用いた計算機システムの構成図である。

【0042】図2に示す計算機システムは、処理装置1300、制御装置1305および1台以上のディスク装置1304により構成されている。

【0043】処理装置1300は、CPU1301、主記憶1302および複数のチャネル1303により構成されている。

【0044】制御装置1305は、処理装置1300からのリード/ライト要求にしたがって、処理装置1300とディスク装置1304の間でデータの転送処理を実行するものであり、2つのクラスタ1311を備えている。

【0045】それぞれのクラスタ1311は、1つ以上のディスクアレイ制御プロセッサ1310、キャッシュメモリ(以下、単にキャッシュと略す。)1308、バス1312、電源1312、交代電源1313を備え、バス1312は反対のクラスタ1311のディスクアレイ制御プロセッサ1310とキャッシュ1308に接続されている。

【0046】電源1313は、当該クラスタ1311の電源を供給するが、交代電源1314は電源1313に障害が発生した時に電源供給を行なう。すなわち、交代電源1314は電源1313の待機系である。なお、図2では、交代電源1314が同一のクラスタ1311の電源1313の待機系になっているが、反対のクラスタ1311の待機系となってもよい。

【0047】キャッシュ1308には、ディスク装置1304の中の一部のデータ、このデータの管理情報、制御装置1305の管理情報などを格納するものであり、信頼性の観点から不揮発化しておくことが望ましい。

【0048】ディスクアレイ制御プロセッサ1310は、制御装置1305内で処理装置1300からのリード/ライト要求を受取り、キャッシュ1308等を利用し、処理装置1300とディスク装置1304の間でデータの転送処理を実行する機能を備えている。

【0049】このディスクアレイ制御プロセッサ1310は、リード/ライト受付部100、ライトアフタ処理実行部101、閉塞移行処理実行部102、回復処理実行部103とから成っている。これら各部の動作については、フローチャートを参照して後述する。

【0050】以下、本実施形態において、制御装置1305が処理装置1300からリード/ライト要求を受け取った時の動作を簡単に説明する。なお、以下に示す動作は、制御装置1305内のディスクアレイ制御プロセッサ1310が実行する。

【0051】まず、制御装置1305が処理装置1300からリード要求を受け取ったときの動作を説明する。【0052】制御装置1305は処理装置1300からリード要求を受け取ったリード時、対象となるレコード500(図5)がキャッシュ1308に格納されていれば、キャッシュ1308内のレコード500を処理装置1300に転送し、動作を完了する。

【0053】しかし、リード対象となるレコード500がキャッシュ1308に格納されていない場合、レコード500をディスク装置1304から読出してキャッシュ1308に転送する。この後、このレコード500をキャッシュ1308から処理装置1300に転送し、動作を完了する。

【0054】一方、制御装置1305が処理装置130 0からのライト要求を受け取った場合、ディスク装置1 304上のレコード500に書き込むべきライトデータ を、キャッシュ1308に格納した段階で動作を完了さ せる。ディスク装置1304へのライトデータの書き込みは、後から制御装置1305が実行する。この処理をライトアフタ処理と呼ぶ。ライトアフタ処理を実行する際、ディスクアレイの構成がRAID3やRAID5の場合、レコード500に対応するパリティデータを作成し、ディスク装置1304に書き込む。RAID1の構成の場合、レコード500の内容を2つのディスク装置1304に書き込む。

【0055】図3は、本実施形態におけるキャッシュ1308の論理的な構造を示す図である。キャッシュ1308は、管理情報格納領域300とディスクデータ格納領域301とから構成される。管理情報格納領域300は、キャッシュ1308に格納したディスク装置1304の中のデータの管理情報および制御装置1305の管理情報を格納するものである。ディスクデータ格納領域301は、ディスク装置1304の中の一部のデータを格納するものである。

【0056】図4は、キャッシュ1308の物理的構造を示す図であり、キャッシュ1308は複数のボード400より構成される。複数のボード400は、大別して管理情報ボード401とディスクキャッシュボード402とから構成されている。

【0057】管理情報ボード401は、管理情報格納領域300に対応したボード400であり、ディスクキャッシュボード402はディスクデータ格納領域301に対応したボード400である。なお、障害の検知の単位は、ボード400単位で行なわれる。

【0058】図5は、ディスクキャッシュボード402へのデータの格納形式を示す図であり、レコード500がディスク装置1305のリード/ライト単位である。レコード500は、m個(m≥2)に分割され、それぞれを分割レコード501として、各分割単位に対応したディスクキャッシュボード402に格納される。

【0059】また、m個の分割レコードからn個(n≥1)の冗長データ502が作成される。m個の分割レコード501とn個の冗長データ502は、それぞれの別々にm+n個のディスクキャッシュボード402に格納される。

【0060】ただし、第1の実施形態ではレコード500に格納形式に冗長性があればよい。例えば、レコード500の内容を2重にディスクキャッシュボード402に格納してもよい。

【0061】なお、1枚のディスクキャッシュボード402に分割レコード501だけを格納したり、冗長データ502だけを格納してもよい。あるいは、1枚のディスクキャッシュボード402に分割レコード501と冗長データ502を混在させて格納してもよい。n個の冗長データ502を格納した場合には、n枚のディスクキャッシュボード402が故障しても、レコード500の内容を復元できる。

【0062】図6は、管理情報ボード400の情報の格納形式を示す図であり、管理情報600は2つの管理情報ボード401に2重に格納される。

【0063】なお、2つの管理情報ボード401をベアにして、2つの管理情報ボード401にまったく同じ管理情報600を格納してもよい。また、管理情報600を任意の2つの管理情報ボード401に格納し、管理情報ボード401全体の情報は、異なっていてもよい。また、第1の実施形態では、管理情報600の格納形式は必ずしも2重に格納する必要はなく、冗長性があればよい。

【0064】本実施形態では、ボード400に障害が発生し、管理情報600やレコード500の格納に冗長性がなくなった時、クラスタ1311を閉塞する前処理の実行に入る。

【0065】すなわち、冗長性のなくなったキャッシュ 1308の使用を停止しようとする。直ちに、閉塞でき ないのは、閉塞しようとするキャッシュ1308に未だ ディスク装置1304に書き込んでいないライトデータ が格納されているためである。

【0066】クラスタ1311を閉塞する前処理とは、閉塞しようとするキャッシュ1308に格納され、ディスク装置1304に書き込んでいないライトデータをディスク装置1304に書き込むか、反対のクラスタ1311のキャッシュ1308にコピーする処理である。同様に、本実施形態では、キャッシュ1308の保守を行おうとした場合、1つのクラスタ1311のキャッシュ1308全体の保守を行うものとする。

【0067】以上より、本実施形態では、それぞれのキャッシュ1308の冗長性がなくなった時、直ちに、冗長性のあるキャッシュ1308を集中して使用するするため、ライトアフタ処理を行っても信頼性を確保できる。

【0068】同様に、一方のクラスタ1311のキャッシュ1308の保守を行う場合も、残りのクラスタ13 11のキャッシュ1308に冗長性があるため、ライト アフタ処理を行っても信頼性を確保できる。

【0069】図7は、キャッシュ1308の状態の遷移をまとめたものである。なお、本実施形態においては、キャッシュ1308が2つあるため、この状態は、それぞれのキャッシュ1308毎に管理するものとする。

【0070】図7において、使用可能状態900は、当該キャッシュ1308が使用可能であることを表す。使用可能状態900から当該キャッシュ1308のボード400の障害を検知したり、保守処理を開始しようとした時、当該キャッシュ1308を閉塞移行中状態901にする。これは、当該キャッシュ1308を閉塞するための前処理を実行中であることを表す。この処理が完了すると、キャッシュ1308の状態は、閉塞状態902になる。

【0071】その後、当該キャッシュ1308の保守が完了したり、障害を起こしたボード400の交換等が完了すると、キャッシュ1308の状態は、回復状態903になる。これは、当該キャッシュ1308を使用可能状態900にするための前処理の実行中である状態を表す。

【0072】図8は、図3に示したディスクデータ格納 領域301の論理的な構造を示す図であり、ディスクデータ格納領域301は複数のセグメント800から構成 される。セグメント800にはレコード500が格納される。

【0073】図9に、レコード500とセグメント800とディスクアレイボード400の関係を示す。セグメント800は、m+n個の分割セグメント910に分割され、それぞれの分割セグメント901には、分割レコード501と冗長データ502が格納される。

【0074】図10は、図3に示した管理情報格納領域300の論理的な構造を示す図であり、本実施形態において管理情報格納領域300に含まれる情報は、自クラスタ内キャッシュ状態1000、他クラスタ内キャッシュ状態1001、セグメント対応のセグメント管理情報1002、空きセグメントキューポインタ1003である。

【0075】自クラスタ内キャッシュ状態1000、他クラスタキャッシュ状態1001は、自分のクラスタ1311のキャッシュ1308、あるいは、他のクラスタ1311のキャッシュ1308が、それぞれ、図7に示した状態のうちのどの状態にあるかを示している。

【0076】セグメント管理情報1002は、図8のセグメント800のそれぞれに対応して存在する管理情報である。空きセグメントキューポインタ1002は、図11に示すように、レコード500を格納していないセグメント800に対応するセグメント管理情報1002を結合した空きセグメントキュー1100の先頭を示すポインタである。

【0077】これらの自クラスタ内キャッシュ状態1000、他クラスタ内キャッシュ状態1001、セグメント管理情報1002、空きセグメントキューボインタ1003のいずれの情報も2重化して2つの管理情報ボード401に格納される。

【0078】図12は、セグメント管理情報1002の詳細を示す図であり、セグメント管理情報1002は、セグメントポインタ1200、使用中ビット1201、ダーティビット1202、ディスクアドレス1203を含んだ構成となっている。

【0079】セグメントポインタ1200は、空きセグメントキュー1100に当該セグメント管理情報100 2が空きセグメントキュー1100につながれている時に、次のセグメント管理情報1002をポイントするためのものである。 【0080】使用中ビット1201は、ディスクアレイ制御プロセッサ1310における各実行部が、当該セグメント管理情報1002に対応するセグメント800に格納されたレコード500のリード/ライト処理を実行中にオンにする。すなわち、リード/ライト処理受付部100、ライトアフタ処理実行部101、閉塞移行処理実行部102、回復処理実行部103などがセグメント800を使用する場合、本ビット1201をオンにする。他の実行部は、使用中ビット1201がオンのセグメント管理情報1201を見出した場合、これがオフになるまで待つ。これにより、各処理の排他が可能になる。

【0081】ダーティビット1202は、当該セグメント管理情報1002に対応するセグメント800に格納されたレコード500の内容が未だディスク装置1304に書き込まれていない、すなわち、ライトアフタ処理を行う必要があるレコード500であることを示す。

【0082】ディスクアドレス1203は、当該セグメント管理情報1002に対応するセグメント800に格納されたレコード500が、どのディスク装置1304内のどのアドレスであるかかを表すものである。

【0083】以下、図13~図16のフローチャートを 用いて本実施形態における制御装置1305内のディス クアレイ制御プロセッサ1310が実行する処理を説明 する。

【0084】なお、2つのクラスタ1311のキャッシュ1308のいずれのキャッシュ1308も使用可能状態900か、回復中状態903にある時、どちらのキャッシュ1308を使用するかは、リード/ライトするレコード500のディスク装置1304のアドレス等により一意に定まるとする。

【0085】図13は、リード/ライト受付部100の処理を示すフローチャートであり、この処理は処理装置1300からリード/ライト要求を受け付けた時に開始される

【0086】まず、ステップ110で、どちらのキャッシュ1308も使用可能状態900の時、どちらのキャッシュ1308を使用するかを決定する。次に、ステップ111で、当該キャッシュ1308の状態を調べる。使用可能状態900の場合には、そのまま当該キャッシュ1308を使用し、ステップ112でリード/ライト処理の実行に入る。

【0087】しかし、閉塞状態902の時には、ステップ113で反対のキャッシュ1308を使用することに決定し、この後、ステップ112ヘジャンプする。

【0088】また、閉塞移行中状態901の場合、まず、ステップ114で当該キャッシュ1308にリード/ライトするレコード500が格納されているかをチェックする。格納されていなければ、ステップ113ヘジ

ャンプする。格納されている場合、ステップ115において、このレコード500の内容を反対のキャッシュ1308にコピーするか、このレコード500の内容がディスク装置1304に書き込まれていないものかどうかを図12のダーティビット1202によってチェックし、書き込まれていなければ、ディスク装置1304に書き込む。

【0089】なお、ディスク装置1304に書き込む時、ディスクアレイの構成がRAID3やRAID5の場合、レコード500に対応するパリティデータを作成し、ディスク装置1304に書き込む。RAID1の構成の場合、レコード500の内容を2つのディスク装置1304に書き込む。

【0090】さらに、ステップ116で、当該キャッシュ1308からこのレコードを消去する。この後、ステップ113ヘジャンプする。

【0091】回復中状態901の場合、ステップ117で反対側のキャッシュ1308にリード/ライトするレコード500が格納されているかをチェックする。格納されていなければ、ステップ112へジャンプする。格納されている場合、ステップ118で、このレコード500の内容を反対のキャッシュ1308にコピーするか、このレコード500の内容がディスク装置1304に書き込まれていないかチェックし、書き込まれていなければ、ディスク装置1304に書き込む。

【0092】なお、ディスク装置1304に書き込みを行なう時、ディスクアレイの構成がRAID3やRAID5の場合、レコード500に対応するパリティデータを作成し、ディスク装置1304に書き込む。RAID1の構成の場合、レコード500の内容を2つのディスク装置1304に書き込む。

【0093】さらに、ステップ119で、当該キャッシュ1308からこのレコードを消去する。この後、リード/ライト処理に入る。

【0094】図14は、ライトアフタ処理実行部101の処理を示すフローチャートであり、その概要は既に説明したように、キャッシュ1308の中に未書き込みのデータをディスク装置1304に書き込むものである(ステップ131)。

【0095】図15は、閉塞移行処理実行部102の処理を示すフローチャートであり、この処理は、当該キャッシュ1308のボード400の障害を検知したり、保守処理を開始しようとした時に開始される。本処理は、当該キャッシュ1308を閉塞するための前処理である。

【0096】具体的には、ステップ120で当該キャッシュ1308の中に格納されているレコード500がないかを調べる。見つかった場合、ステップ121で、このレコード500の内容を反対のキャッシュ1308に

コピーするか、このレコード500がライトアフタ処理を行なう必要があるかをチェックし、ライトアフタ処理を行なう必要がある未書き込みデータならば、その内容をディスク装置1304に書き込む。

【0097】なお、ディスク装置1304に書き込む時、ディスクアレイの構成がRAID3やRAID5の場合、レコード500に対応するパリティデータを作成し、ディスク装置1304に書き込む。RAID1の構成の場合、レコード500の内容を2つのディスク装置1304に書き込む。

【0098】この後、このレコード500を当該キャッシュ1308から消去する。当該キャッシュ1308に格納されたレコード500がなくなった時、ステップ122で、当該キャッシュ1308の状態を閉塞状態902にして処理を完了する。

【0099】図16は、回復処理実行部103の処理を示すフローチャートであり、この処理は、当該キャッシュ1308の保守が完了したり、障害を起こしたボード400の交換等が完了したときに開始される。本処理は、当該キャッシュ1308を使用可能状態900にするための前処理である。

【0100】まず、ステップ123で、反対のキャッシュ1308の中に、当該キャッシュ1308に格納すべきレコード500がないかをチェックする。見つかった場合、ステップ124で、このレコード500の内容を当該キャッシュ1308にコピーするか、このレコード500がライトアフタすべきレコード500であれば、その内容をディスク装置1304に書き込む。

【0101】なお、ディスク装置1304に書き込む時、ディスクアレイの構成がRAID3やRAID5の場合、レコード500に対応するパリティデータを作成し、ディスク装置1304に書き込む。RAID1の構成の場合、レコード500の内容を2つのディスク装置1304に書き込む。

【0102】この後、当該レコード500を反対のキャッシュ1308から消去する。反対のキャッシュ1308に格的すべきレコード500がなくなった時、ステップ125で、当該キャッシュ1308の状態を使用可能状態902にして処理を完了する。

【0103】ここで、リード/ライト処理受付部100とライトアフタ処理実行部101と閉塞移行処理実行部102の処理は並列に実行される。各処理の排他は、キャッシュ1308のセグメント管理情報1002中の使用ビット1201を用いて実行される。同様に、リード/ライト処理受付部100とライトアフタ処理実行部101と回復処理実行部103の処理も並列に実行される。この場合も、各処理の排他は、キャッシュ1308の使用ビット1201を用いて実行される。

【0104】本実施形態では、それぞれのクラスタ内の

データの格納形式にRAID3のような冗長性を持たせ、クラスタ間ではキャッシュメモリに格納するデータを重複させないようにしておく。さらに、保守処理を行なう際には、保守を行うキャッシュメモリは新たにデータの格納を行なわないようにし、保守を行うキャッシュメモリにそれまで格納していたデータを、もう一方のクラスタのキャッシュメモリに書き込むか、ディスク装置に書き込むようにした。以上により、保守処理中の信頼性を向上させることができるという効果がある。

【0105】次に、本発明の第2の実施形態について説明する。

【0106】図17は、本発明を適用した計算機システムの第2の実施の形態を示す構成図である。

【0107】この第2の実施形態と前述した第1の実施 形態との構成上の相違点は、次の通りである。

【0108】(1)制御装置1305がクラスタ131 1を持たない。

【0109】(2)第2の実施形態の制御装置1305が2本のバス1312を持っている。

【0110】(3) キャッシュ1308の管理情報格納 領域300の構成が異なる。

【0111】この実施形態における管理情報格納領域300の構成を図18に示す。この実施形態の管理情報格納領域300は、キャッシュ状態1400、セグメント対応のセグメント管理情報1002、空きセグメントキューボインタ1003で構成されている。第1の実施形態との相違は、キャッシュ1308が1つしかないため、キャッシュ1308の状態が1つしかない点である。

【0112】これ以外の図3~図6、図8~図9、図11~図12の構成は、第2の実施形態でも適用できる。【0113】但し、本実施形態では、管理情報600は図6に示したように必ず2つの管理情報ボード401に格納される。また本実施形態では、図5に示した通り、レコード500は、RAID3の形式で各ディスクキャッシュとボード402に必ず格納される。

【0114】本実施形態では、キャッシュ1308は1つしかないため、障害時のキャッシュ1308の閉塞の単位はボード400となる。同様に、キャッシュ1308の保守の単位もボード400である。

【0115】図19は、本実施形態におけるキャッシュ1308の状態遷移をまとめたものである。正常状態1500は、キャッシュ1308に冗長度がある状態である。この状態で、制御装置1305が処理装置1300からライト要求を受け取った時には、ライトデータをキャッシュ1308に書き込んだ段階で処理を完了する。【0116】キャッシュ1308のボード400に障害が発生したり、保守処理を実行する際に、キャッシュ1308の冗長度がなくなる時、冗長度なし移行状態1501で

は、キャッシュ1308の中に、レコード500の内容をディスク装置1304に書き込んでいないすべてのレコード500について、その内容をディスク装置1304に書き込む処理が実行される。これが完了すると、キャッシュ1308の状態は、冗長度なし状態1502に遷移する。

【0117】また、キャッシュ1308の状態が正常状態1600以外の時には、信頼性の観点から、制御装置1305は、ライト要求を受け取ったとき、ライトデータをディスク装置1304に書き込んだ段階で処理を完了させる。

【0118】なお、リード要求に対する制御装置130 5の動作は、キャッシュ1308の状態によらず、第1 の実施形態の場合と同じである。

【0119】図20は、制御装置1305内のディスクアレイ制御プロセッサ1310の構成を示した図であり、リード/ライト受付部1600、冗長なし移行処理実行部1601、ライトアフタ処理実行部101で構成されている。

【0120】以下、図21および図22のフローチャートを参照してディスクアレイ制御プロセッサ1310が実行する処理を説明する。なお、ライトアフタ処理実行部101は、第1の実施形態と同じであるので、その説明は省略する。

【0121】図21は、リード/ライト受付部1600の処理を示すフローチャートであり、リード/ライト受付部1600は処理装置1300からリード/ライト要求を受け付けた時に動作を開始する。

【0122】まず、ステップ1610で、リード要求とライト要求のどちらを受け取ったかを判別する。リード要求であった場合、ステップ1611で、リード処理の実行に入る。ライト要求の場合、ステップ1612で、キャッシュ1308の状態を分析する。

【0123】キャッシュが正常状態の場合、ステップ1613で、処理装置1300から受け取ったライトデータをキャッシュ1308に書き込み動作を終了させる。 冗長なし状態1502の場合、ステップ1614で、処理装置1300から受け取ったライトデータをディスク装置1304に書き込み、動作を終了させる。

【0124】冗長度なし移行状態1501の場合、図22に示す冗長なし移行処理実行部1601の処理が開始される。

【0125】この冗長なし移行処理では、ステップ1615で、レコード500の内容がディスク装置1304に書き込まれていないかチェックし、書き込まれていれば、ステップ1617にジャンプし、キャッシュ状態を冗長なし状態1502に更新する。書き込まれていない場合、ステップ1616で、その未書き込みレコード500をディスク装置1305に書き込む。その後、ステップ1615へジャンプする。

【0126】なお、ステップ1614およびステップ1616で、ディスク装置1304に未書き込みレコード500を書き込む時、ディスクアレイの構成がRAID3やRAID5の場合、レコード500に対応するパリティデータを作成し、ディスク装置1304に書き込む。RAID1の構成の場合、レコード500の内容を2つのディスク装置1304に書き込む。

【0127】その後、キャッシュ1308の中に、ディスク装置1304にその内容を書き込んでいないレコード500がなくなった時、ステップ1617でキャッシュ1308の状態を冗長なし状態1502に更新して処理を完了する。

【0128】以上の説明から明らかなように、本実施形態によれば、ライトデータをRAID3の形式で格納し、キャッシュの管理情報をRAID1の形式で格納するようにしたため、信頼性をそれほど損なうことなく、記憶効率を従来に比べて向上させることができる。

[0129]

【発明の効果】以上のように本発明においては、ディスクキャッシュのライトデータの格納形式をRAID3の形式とし、キャッシュの管理情報をRAID1の形式で格納するようにしたため、信頼性を損なうことなく、記憶効率を従来に比べて向上させることができる。

【0130】一方、本発明では、複数のクラスタで構成されるディスク制御装置の場合には、それぞれのクラスタ内のデータの格納形式に冗長性を持たせ、さらに保守処理を行なう際には、保守を行うキャッシュメモリには、新たにデータの格納を行なわないようにし、保守を行うキャッシュメモリにそれまで格納していたデータをもう一方のクラスタのキャッシュメモリに書き込むか、ディスク装置に書き込むようにするようにした。これにより、保守処理中の信頼性を向上させることができるという効果が得られる。

【図面の簡単な説明】

【図1】本発明を適用したディスクアレイ制御プロセッサの第1の実施形態を示す構成図である。

【図2】図1のディスクアレイ制御プロセッサを用いた 計算機システムの構成図である。

【図3】キャッシュメモリの論理的構成図である。

【図4】キャッシュメモリの物理的構成図である。

【図5】ディスクキャッシュボードのレコードの格納形 式を示す図である。

【図6】管理情報ボードの情報格納形式を示す図であ る

【図7】第1の実施形態におけるキャッシュメモリの状態遷移を示す図である。

【図8】 ディスクデータ格納領域の論理的構成図である。

【図9】セグメントの物理的格納形式を示す図である。 【図10】第1の実施形態における管理情報格納領域の 論理的構成図である。

【図11】空きセグメントキューの説明図である。

【図12】セグメント管理情報の構成図である。

【図13】第1の実施形態におけるリード/ライト受付 部の処理を示すフローチャートである。

【図14】第1の実施形態におけるライトアフタ処理実 行部の処理を示すフローチャートである。

【図15】第1の実施形態における閉塞移行処理実行部の処理を示すフローチャートである。

【図16】第1の実施形態における回復処理実行部の処理を示すフローチャートである。

【図17】本発明の第2の実施形態を示す構成図である。

【図18】第2の実施形態における管理情報格納領域の 論理的構成図である。

【図19】第2の実施形態におけるキャッシュ1308の状態遷移を示す図である。

【図20】第2の実施形態におけるディスクアレイ制御

プロセッサの構成図である。

【図21】第2の実施形態におけるリード/ライト受付部の処理を示すフローチャートである。

【図22】第2の実施形態における冗長なし移行処理実 行部の処理を示すフローチャートである。

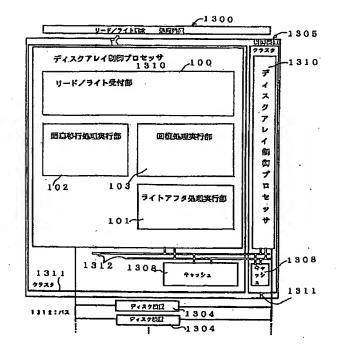
【符号の説明】

100,1600…リード/ライト受付部、101…ライトアフタ処理実行部、102…閉塞移行処理実行部、103…回復処理実行部、300…管理情報格納領域、301…ディスクデータ格納領域、400…ボード、401…管理情報ボード、402…ディスクキャッシュボード、500…レコード、501…分割レコード、502…冗長データ、800…セグメント、901…分割セグメント、1300…処理装置、1304…ディスク装置、1305制御装置、1308…キャッシュメモリ、1310…ディスクアレイ制御プロセッサ、1311…クラスタ、1312…バス、1313…電源、1314…交替電源、1601…冗長なし移行処理実行部。

【図14】

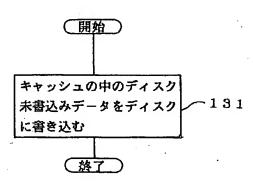
【図1】

図1

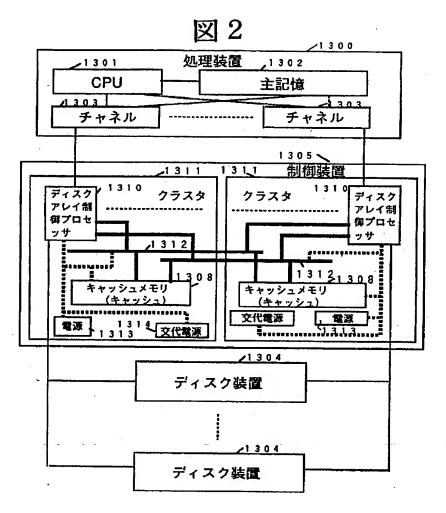


F 1 4

ライトアフタ処理実行部



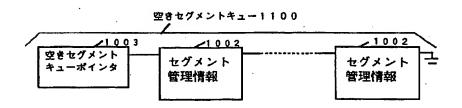
【図2】



1312:バス

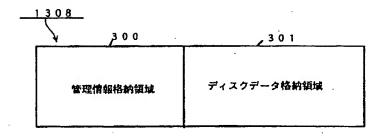
【図11】

図 1 1



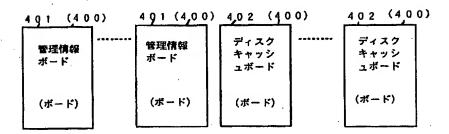
【図3】

図 3

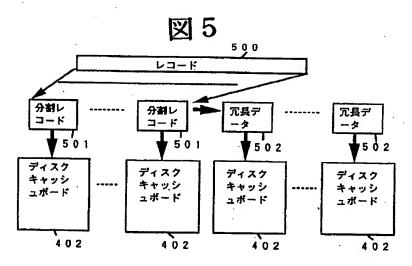


【図4】

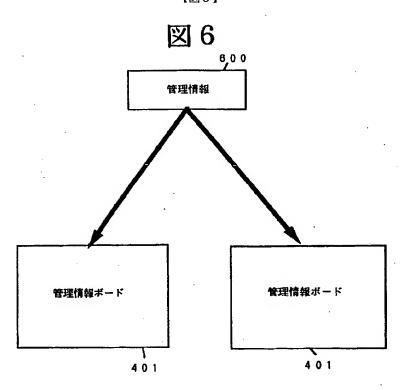
図 4



【図5】

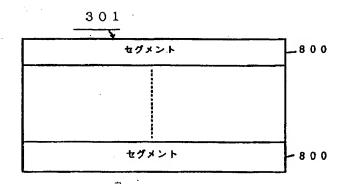


【図6】

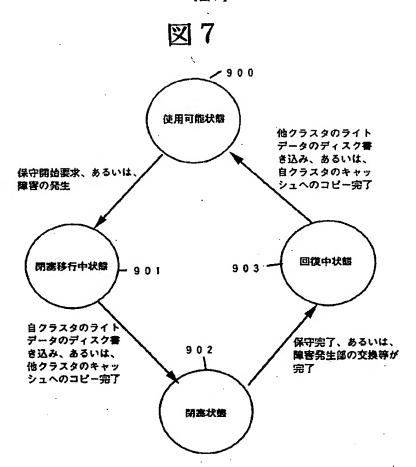


【図8】

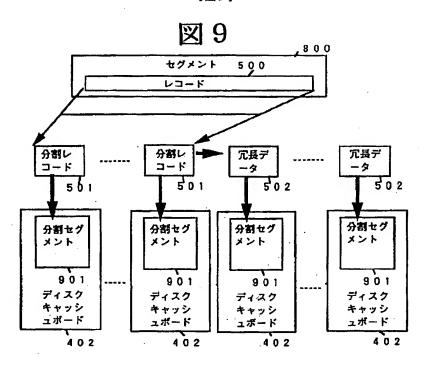
図 8



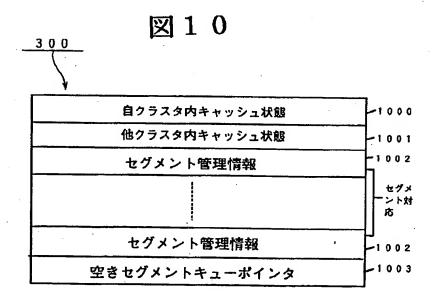
【図7】



【図9】

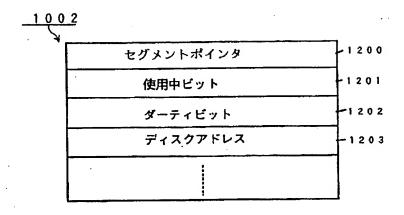


【図10】



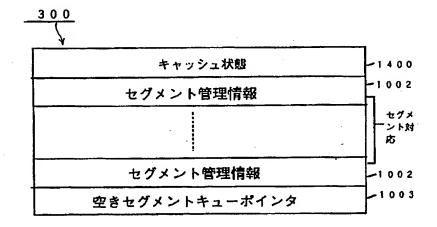
【図12】

図 1 2

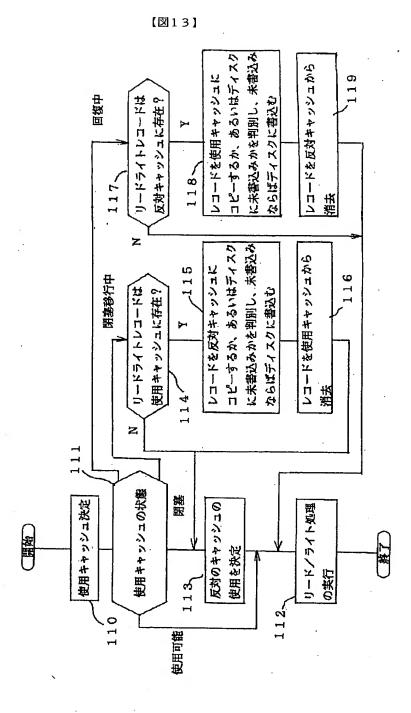


【図18】

図18



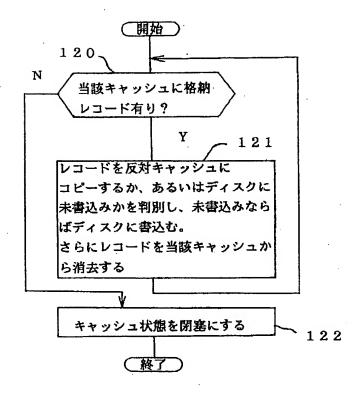




【図15】

図15

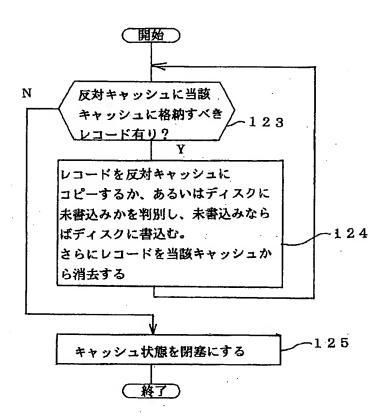
閉塞移行処理実行部



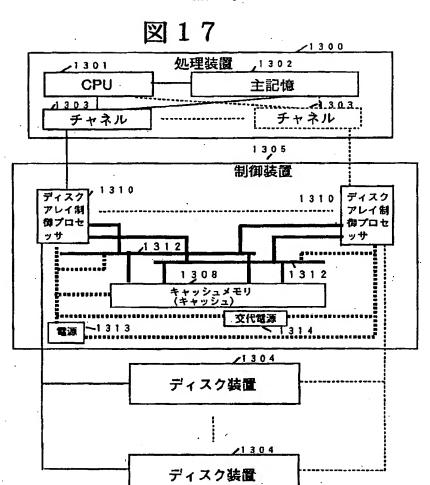
【図16】

図 16

回復処理実行部



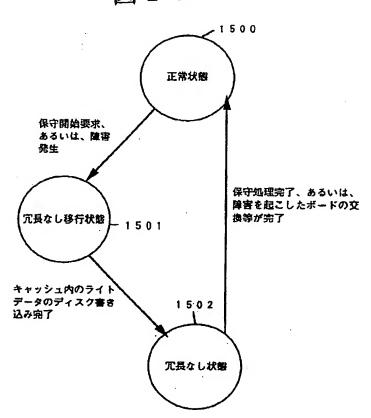
【図17】



1312:バス

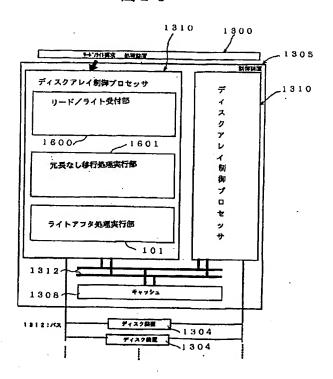
【図19】

図19



【図20】

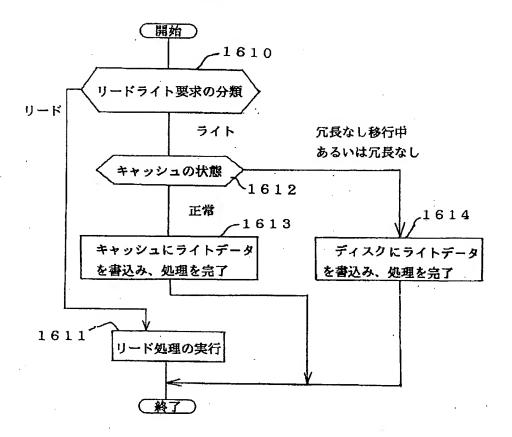
図20



【図21】

図21

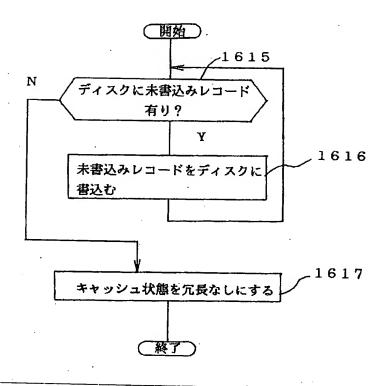
リードライト受付部



【図22】

図 2 2

冗長なし移行処理実行部



フロントページの続き

(51) Int. Cl.6

識別記号

庁内整理番号

FΙ

G06F 12/08

技術表示箇所

310 320

7623-5B 7623-5B

310Z 320

(72)発明者 安積 義弘

G06F 12/08

神奈川県小田原市国府津2880番地 株式会 社日立製作所ストレージシステム事業部内